

Uso de una red neuronal para la fusión de lecturas de sonares en robots móviles

Leonardo Romero M.

lromero@zeus.ccu.umich.mx
ITESM Campus Morelos, México

Eduardo Morales M.

emorales@campus.mor.itesm.mx
ITESM Campus Morelos, México

Resumen

Se evalúa el uso de una red neuronal tipo retropropagación para la fusión de lecturas de sonares de un robot móvil. El propósito es construir un mapa métrico de ocupación alrededor del robot, siguiendo las ideas presentadas en [Thrun, 1998a; 1998b]. Los ejemplos de entrenamiento para la red neuronal se obtuvieron utilizando un simulador de un robot móvil, el cual utiliza un modelo simple de operación de los sonares. Se describen algunas estrategias de entrenamiento de la red neuronal para mejorar y acelerar el aprendizaje. Para evaluar el aprendizaje logrado por la red, el error obtenido por la red se compara con el error calculado en base a las probabilidades condicionales estimadas directamente de los ejemplos de entrenamiento. Los resultados de ambos métodos resultan comparables, indicando un aprendizaje de la red satisfactorio. Al final se presentan resultados preliminares obtenidos al usar la red entrenada en la operación de un robot móvil con un sonar giratorio.

1 Introduction

El sonar ha demostrado ser muy eficiente para evitar obstáculos, seguirle la pista a un blanco cercano [Russell and Stuart, 1996] y construir mapas de ambientes de oficina [Thrun, 1998a]. El sonar emite un cierto sonido y mide el tiempo transcurrido en recibir el eco, el cual es utilizado para estimar la distancia del objeto que reflejó el sonido.

Algunas de las dificultades del uso del sonar se desprenden de la geometría de emisión del sonido (véase la Figura 1), donde el lóbulo principal de emisión es de alrededor de 30 grados. Esto hace que el sonar no sea muy preciso para la determinación angular exacta de obstáculos. Otro problema importante con el uso del sonar surge del hecho de que la mayoría de las superficies reflejan el sonido en forma especular. Esto es, el sonido

se comporta en forma similar a un haz de luz que incide en un espejo, donde el ángulo de incidencia es igual al ángulo de reflexión. Esto ocasiona que el sonido emitido por el sonar cuando alcanza una superficie con un cierto ángulo crítico, no regrese al sonar y por lo tanto no se detecte su eco. El ángulo crítico de incidencia con respecto a la normal a la superficie depende del tipo de superficie. Por ejemplo, es mayor en superficies rugosas que en superficies lisas.

Para tratar estos problemas se han sugerido diversas formas de integrar la información de varios sonares con diferentes posiciones o ángulos. El objetivo es mejorar la estimación de distancia y dirección de los obstáculos, al integrar las mediciones realizadas en un mapa. En el área de robot móviles se denomina mapa a cualquier modelo del ambiente del robot empleado con fines de navegación.

Un tipo de mapa frecuentemente utilizado en robot móviles es un mapa de celdas de ocupación [Elfes, 1989]. Este tipo de mapa considera el ambiente del robot como un plano dividido en celdas regulares, normalmente cuadradas, donde a cada celda del mapa se le asocia una probabilidad de ocupación. El mapa construido puede utilizarse para planear trayectorias de movimiento del robot. Algunas técnicas de planeación bien conocidas para la planeación eficiente de trayectorias en mapas de celdas pueden consultarse en [Latombe, 1991] [McKerrow, 1991] [Lee, 1996].

En este trabajo se parte de la idea de usar una red neuronal para la integración de las lecturas de los sonares [Thrun, 1998a] en un mapa de celdas de ocupación local alrededor del robot. Se implementó un simulador de redes neuronales tipo retropropagación y un simulador de un robot móvil en ambientes interiores modelando la operación de los sonares. Utilizando el simulador se obtuvieron ejemplos para el entrenamiento de la red neuronal y se probaron diversas estrategias de aprendizaje. Para tener una medida del aprendizaje de la red, se comparó el error obtenido con el error obtenido al calcular las probabilidades condicionales directamente de los datos de entrenamiento. Finalmente, la red entrenada se insertó en un robot móvil con el fin de observar el

desempeño de la red.

Este trabajo se estructura como sigue. En la sección 2 se presentan los trabajos relacionados con fusión de lecturas de sonares. Se presenta la estructura de la red neuronal empleada por Thrun [1998a], así como el modelo del sonar empleado para entrenar la red. La sección 3 muestra la metodología empleada. Los resultados de la evaluación del desempeño de la red neuronal se presentan en la sección 4. Finalmente, en la sección 5 se presentan las conclusiones.

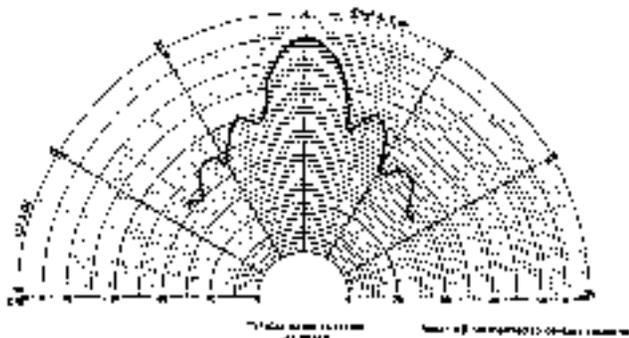


Figura 1: Geometría de emisión del sonido del sonar (Polaroid Corp.).

2 Trabajos relacionados

En la literatura se describen diversas formas de utilización del sonar. Desde un solo sonar con capacidad de girar [Leonard and Durrant-Whyte, 1992], hasta uno o más arreglos de sonares situados a diferentes alturas. Una arreglo común es en forma de anillo, con los sonares uniformemente espaciados y orientados radialmente. Por ejemplo, [Thrun, 1998a] utiliza robots móviles comerciales que disponen de un anillo de 24 o 16 sonares.

Leonard y Durrant-Whyte [1992] usaron un solo sonar giratorio realizando mediciones cada 0.588 grados y buscando lo que llamaron *regiones de constante profundidad, RCP*. Una RCP la definieron como una región donde las lecturas contiguas del sonar no difieren más de 1 cm y tiene al menos un ancho mínimo (típicamente de 10 grados). Con la creación de las RCP se mostró una forma efectiva para el garantizar que las lecturas provienen del lóbulo central de emisión del sonar. La limitación práctica del método es el tiempo empleado en realizar las lecturas.

Lee [1996] también utiliza un solo sonar giratorio, realizando las lecturas cada 18 grados. Las lecturas de los sonares que indican el rango máximo del sensor (2.53 m.) son desechadas. En las lecturas restantes se buscan grupos de lecturas adyacentes cuyos valores no difieran por más de 3 cm. La lectura del grupo se calcula como la mínima de las lecturas involucradas y la dirección como el promedio de direcciones, guardando además la

cantidad de lecturas que formaron el grupo. En la construcción del mapa de características que realiza también toma en cuenta lo que llama *ángulo de visibilidad* de las características de los objetos puntuales y de las superficies planas. El ángulo de visibilidad es el mayor ángulo con respecto a la normal al objeto, al cual puede tomarse una lectura del sonar sin obtener cambios significativos con respecto al valor real. Experimentalmente determinó un valor de 25.2 grados para características de objetos puntuales y 61.2 grados para superficies planas.

También han sido empleadas redes neuronales artificiales para tratar de capturar la dependencia de lecturas de sonares adyacentes [Thrun, 1998a; 1998b]. La idea es entrenar una red neuronal tipo retropropagación, para mapear las lecturas de los sonares a valores de ocupación [Thrun, 1993]. La red tiene una capa de entrada con 6 unidades, una capa oculta (en la referencia no se menciona el número de unidades ocultas) y una sola unidad de salida (véase la Figura 2). La entrada consiste de:

- dos valores que codifican a (x,y) en coordenadas polares relativas al robot (ángulo al primero de los cuatro sonares y distancia), y
- las 4 lecturas de los sonares más cercanos a (x,y) .

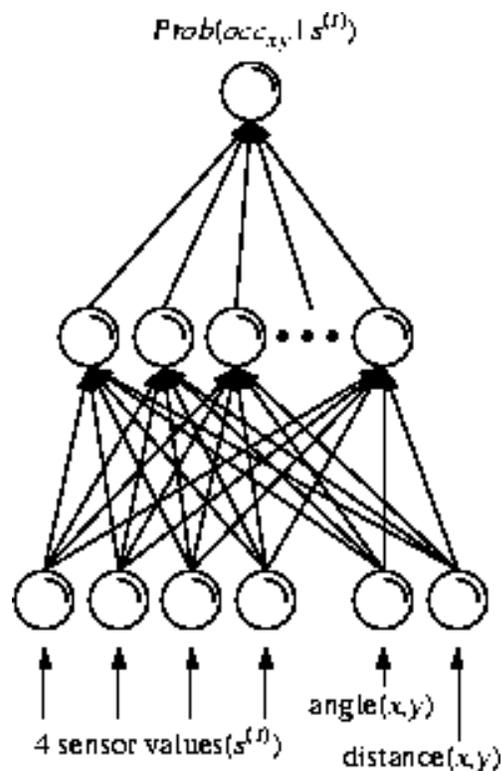


Figura 2: Uso de una red neuronal para el cálculo de la probabilidad de ocupación de una celda dadas cuatro lecturas de sonares cercanas [Thrun, 1998b]

La salida deseada de la red es 1, si (x,y) esta ocupada, y 0 en otro caso. Los ejemplos de entrenamiento pueden ser obtenidos operando el robot en un ambiente conocido, y registrando las lecturas de los sonares. Nótese que cada lectura del sonar puede ser usada para construir muchos ejemplos de entrenamiento para diferentes coordenadas (x,y) .

Thrun usa en su implementación un simulador de un robot móvil para facilitar la recolección de los datos de entrenamiento. Su simulador simula el sonar de la siguiente forma: el lóbulo principal de emisión del sonar es aproximado por un conjunto de 6 rayos. Para cada rayo, una de los siguientes valores se selecciona al azar: 1) un valor aleatorio pequeño, 2) la distancia correcta o 3) un valor aleatorio grande. La probabilidad de los eventos dependen del ángulo entre el rayo y la superficie normal al obstáculo. Este modelo no toma en cuenta otros lóbulos fuera del principal, las reflexiones que involucran más de un obstáculo, la interferencia entre sonares, ni las dependencias temporales en el ruido del sensor. No obstante, se reporta que la red entrenada con su simulador genera buenas interpretaciones. La red entrenada genera valores en el rango $[0,1]$ que pueden ser interpretados como probabilidades de ocupación.

3 Metodología

El cálculo de las lecturas del sonar se realiza en base a las distancias reportadas por seis rayos con una separación angular de 6 grados, cubriendo el total un rango de 30 grados, el ángulo aproximado del lóbulo principal de emisión del sonar. El modelo implementado regresa la menor distancia de los seis rayos, con una cierta variación aleatoria pequeña, si el ángulo de incidencia con la pared es menor que el ángulo crítico asociado a la pared (15 grados para todas las paredes); En otro caso regresa un valor aleatorio cercano a la lectura máxima del sonar.

El ambiente del robot dentro del simulador está construido solamente en base a paredes verticales y horizontales. Con ello, se pueden construir pasillos, cuartos, puertas, etc.

Utilizando el simulador, se generaron manualmente algunos ejemplos de entrenamiento y con ellos se entrenó una red neuronal tipo retropropagación de tres capas, seis unidades de entrada y una unidad de salida. Usando cuatro sonares dispuestos con diferencias de 15 grados, se discretizó en celdas cuadradas de 10×10 cm. el espacio comprendido entre la orientación del segundo y tercer sonar (15 grados) hasta una distancia de 3 metros. Para el entrenamiento, se utilizo la siguiente convención. Si al disparar los cuatro sonares, una determinada celda se encuentra entre el robot y la pared, el valor de la salida es 0 (desocupado), si está muy cercana a la pared, el valor es de 1 (ocupado), y si está después de la pared, su valor es de 0.5 (incierto).

4 Resultados

Se probó el desempeño de las redes con 2, 3, 6, 12, 15, 30, 90 unidades ocultas, obteniéndose los mejores resultados de aprendizaje utilizando una red con 6 neuronas ocultas. En la Figura 3 se muestra el desempeño de la red cuando existe una pared enfrente del robot. En la Figura cada celda se presenta como un pequeño círculo, donde el nivel de gris corresponde a la probabilidad de ocupación. En este caso, la respuestas de la red corresponden al comportamiento esperado. Sin embargo, en algunas situaciones, se generaban respuestas erróneas como la mostrada en la Figura 4. Estos resultados se explican debido a que la red se entrenó con pocos ejemplos.

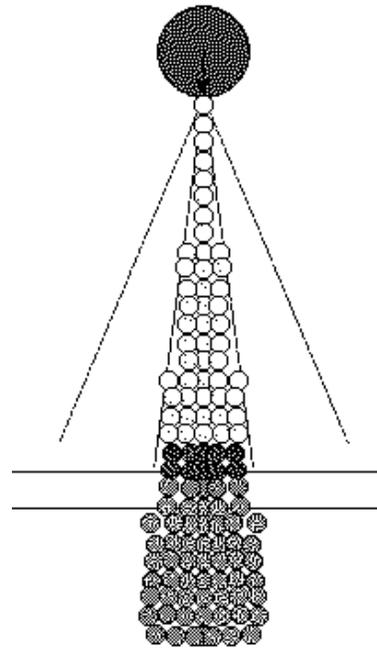


Figura 3: Resultado de la interpretación de sensores ante una pared frontal para un tamaño de ventana de 3 metros.

Un efecto interesante de la operación del sonar se ilustra en la Figura 5. Para una longitud de 3 m. y puertas de 1 metro de ancho, el robot puede interpretar las lecturas de los sonares como si existiera una pared enfrente de él. Por este motivo, en las siguientes pruebas se disminuyó la longitud de 3 m a 2 m. Además, para disminuir el tiempo de aprendizaje de la red, se aumentó el tamaño de las celdas a $20 \text{ cm.} \times 20 \text{ cm.}$

En los siguientes experimentos que se realizaron, los ejemplos de entrenamiento se generaron automáticamente aprovechando las ventajas de programación del

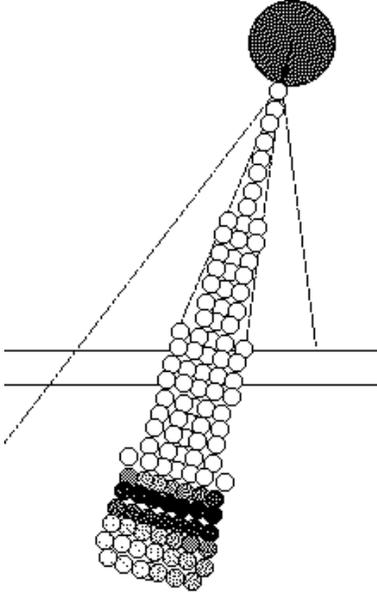


Figura 4: Resultado de la interpretación de sensores ante una pared con cierta inclinación, para un tamaño de ventana de 3 m.

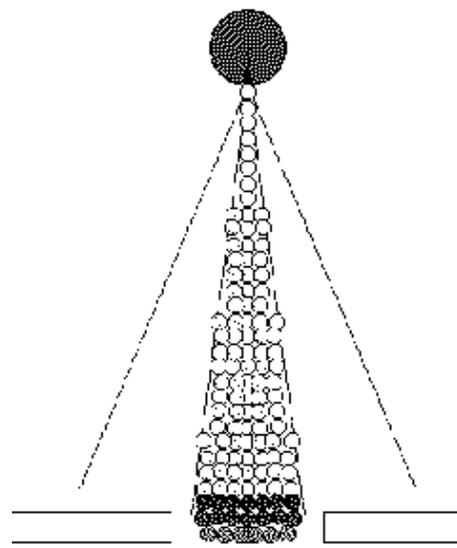


Figura 5: Interpretación de sonares cerrando una puerta cuando se utiliza un mapa local de 3m de longitud.

simulador del robot móvil desarrollado. Se programó la trayectoria a seguir por el robot, variando tanto la posición como su orientación y realizando disparos con sus cuatro sonares. De esta manera se generó un conjunto de entrenamiento de 25186 ejemplos.

4.1 Análisis del error de aprendizaje

Para tener una estimación del aprendizaje realizado por la red, se comparó el error obtenido con el obtenido mediante las probabilidades condicionales estimadas directamente de los ejemplos de entrenamiento. La estimación de las probabilidades condicionales directamente de los datos se calculó de acuerdo a:

$$P(O_{xy} = oc | s_1 = v_1, s_2 = v_2, s_3 = v_3, s_4 = v_4) = \frac{n_c + mp}{n + m}$$

Donde:

O_{xy} es el estado de ocupación de la celda (x,y) que asume el valor ocupado (oc).

S_i es el i-ésimo sonar que entrega la lectura v_t

n_c es el número de ejemplos para los cuales $O_{xy} = oc$, $S_1 = v_1$, $S_2 = v_2$, $S_3 = v_3$ y $S_4 = v_4$.

n es el número de ejemplos para los cuales $S_1 = v_1$, $S_2 = v_2$, $S_3 = v_3$ y $S_4 = v_4$.

m es el tamaño de muestra equivalente

p es la estimación a priori de la probabilidad a determinar

Los valores de los sonares se discretizaron en 25, 50 y 100 intervalos regulares. Se realizaron pruebas con valores de $m = 1, 3$ y 5 ; y un valor de $p = 0.5$.

Con un valor de m de 1, los valores del error E , definido como la raíz cuadrada de la suma de los cuadrados de los errores de cada ejemplo de entrenamiento, fueron los siguientes:

- $E = 26.82$ para el caso de 25 intervalos
- $E = 23.38$ para el caso de 50 intervalos
- $E = 22.69$ para el caso de 100 intervalos

Para valores de m de 3 y 5 el valor de error se incrementó en los tres casos de la discretización. En el caso de la red neuronal se obtuvo un valor de error de 22.86, comparable al error de 22.69 obtenido directamente de los datos.

4.2 Estrategias de aprendizaje

Enseguida se presentan algunas heurísticas de las cuales se obtuvo cierta evidencia de que mejoraban el desempeño de la red y/o disminuían el tiempo de aprendizaje.

La regla de actualización de pesos estocástica (donde los pesos de la red se modifican después de presentarse cada patrón de entrenamiento) disminuía más

rápidamente el error inicial de la red pero tendía a estabilizarse el error en un valor alto (mínimo local). En contraste la regla delta generalizada, que actualiza los pesos de la red una vez que se han presentado todos los patrones de entrenamiento, tendía a disminuir menos rápidamente el error inicial de la red, pero se estabilizaba en valores de error menores que la otra forma de actualización. En base a estas observaciones, se utilizó la regla de actualización estocástica en la etapa inicial del aprendizaje hasta que se alcanzaba una cierta estabilidad. En adelante se utilizaba la otra forma del cambio de pesos. Con esto se obtuvieron menores errores de la red, así como tiempos más cortos de aprendizaje.

En las pruebas de aprendizaje de la red se encontró que resultaba más rápido utilizar valores de 1.0 (ocupado) en lugar de 0.5 (incierto) para el estado de ocupación de las celdas. Los ejemplos donde las lecturas de los sonares eran máximas se eliminaron. Esto con el fin de disminuir los ejemplos contradictorios: de espacio libre, y pared inclinada enfrente del robot; donde los sonares reportarían lecturas máximas.

Al observar la respuesta de la red, se observó que ciertas respuestas no resultaban congruentes con las esperadas. Por ejemplo, ante una pared enfrente del robot, las celdas correspondientes a la posición de la pared aparecían como desocupadas, y las celdas un poco después de la pared aparecían como ocupadas. Para mejorar el desempeño de la red, se agregaron ejemplos de entrenamiento para las situaciones donde se observó este efecto (alrededor de 300 ejemplos).

En otra prueba, el rango de lecturas de los sonares se discretizó usando 50 intervalos uniformes y se eliminaron los ejemplos repetidos. De esta forma, se redujeron los ejemplos de entrenamiento de 25186 a 4720, resultando en un tiempo de aprendizaje de la red significativamente menor.

Para el ambiente mostrado en la Figura 6, la Figura 7 muestra un ejemplo de la interpretación de los sonares utilizando la red obtenida y aplicando las heurísticas antes mencionadas. Las celdas están indicadas por pequeños círculos cuyo nivel de gris depende de la probabilidad de ocupación de la celda. Un color blanco indica que la celda está libre y un color negro indica que está ocupada. La Figura 7 muestra que la red proporciona una buena estimación de las áreas libres cercanas al robot. Los resultados mostrados consideran un tamaño de ventana de 2m. y celdas de 20 * 20 cm.

4.3 Implementación de la red en un robot móvil

La red entrenada se integró a un robot móvil (ver Figura 8) con un sonar con capacidad de giro de 180 grados. Se programó al robot para disparar el sonar a intervalos angulares de 15 grados, desde -90 grados hasta 90 grados, un total de 13 disparos. Para calcular el estado de ocupación de una determinada celda, se alimentaron como

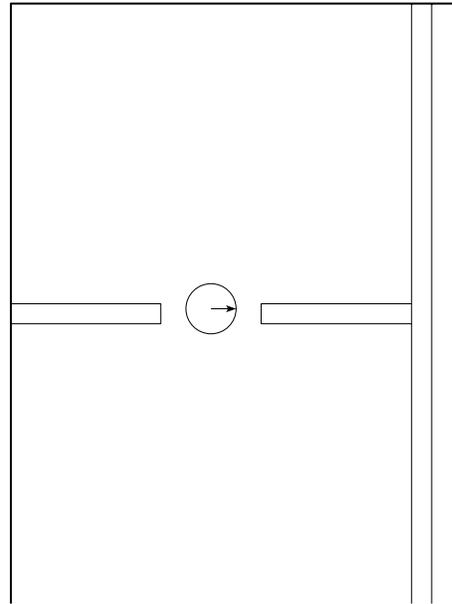


Figura 6: Ambiente del robot.

entrada a la red las lecturas de los cuatro sonares más cercanos al ángulo correspondiente a la celda. Esto es, la misma red se aplicaba para todos los sonares, haciendo grupos de cuatro sonares consecutivos.

Resultados preliminares muestran que el mapa local construido alrededor del robot, usando este esquema de fusión sensorial, logra capturar los obstáculos alrededor del robot.

5 Conclusiones

Los resultados obtenidos sugieren que el uso de una red neuronal de tipo retropropagación, con cuatro unidades de entrada, 6 unidades ocultas y 1 unidad de salida, logra integrar las lecturas de cuatro sonares para dar una buena estimación del espacio libre alrededor del robot. El error de la red entrenada resultó ser semejante al calculado a partir de las probabilidades condicionales estimadas directamente de los ejemplos de entrenamiento.

El aprendizaje de la red puede mejorarse utilizando una estrategia de actualización de los pesos de la red después de cada patrón de entrenamiento en la etapa inicial y continuando después con la actualización de pesos al final de alimentar todos los patrones de entrenamiento. Se obtuvieron buenos resultados al eliminar los ejemplos de lecturas máximas de sonares, ejemplos repetidos (usando cierto criterio de discretización de las lecturas de los sonares), y agregar nuevos ejemplos en las situaciones donde claramente se equivoca la red.

Referencias

[Elfes, 1989] A. Elfes. *Using Occupancy Grids for Mobile Robot Perception and Navigation*. IEEE Computer,

[Latombe, 1991] J.-C. Latombe. *Robot Motion Planning* Kluwer Academic Publishers.

[Lee, 1996] David Lee. *The Map-Building and Exploration of a Simple Sonar-Equipped Robot*. Cambridge University Press.

[Leonard and Durrant-Whyte, 1992] J.J. Leonard and H.F. Durrant-Whyte. *Directed Sonar Sensing for Mobile Robot Navigation*. Kluwer Academic Publishers.

[McKerrow, 1991] P.J. McKerrow. *Introduction to Robotics* Addison-Wesley.

[Russell and Stuart, 1996] Stuart Russell and Peter Norvig. *Inteligencia Artificial Un Enfoque Moderno*. Prentice Hall Hispanoamericana S.A. p. 827.

[Thrun, 1993] Sebastian Thrun. Exploration and Map Building in Mobile Robot Domains. In Raspini, E., editor. *Proceedings of the ICMM-93*. pp. 175-180, San Francisco, CA. IEEE Neural Network Council.

[Thrun, 1998a] Sebastian Thrun. Map Learning and High-Speed Navigation in RHINO. In Kortenkamp, D.; Bonasso, R.P.; and Murphy, R. *Artificial Intelligence and Mobile Robots*. AAAI Press/The MIT Press.

[Thrun, 1998b] Sebastian Thrun. Learning Maps for Indoor Mobile Robot Navigation. *Artificial Intelligence*, 99(1), 21-71

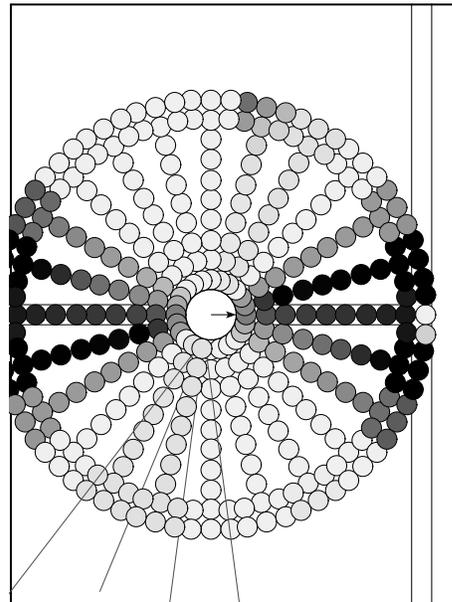


Figura 7: Interpretación de los sonares



Figura 8: Robot móvil de pruebas.